

基于生成对抗网络的单张 SAR 欺骗干扰模板增广方案研究¹

李贵强¹, 程时楠¹, 祁首冰²✉

1) 北京工业大学信息科学技术学院, 北京 100124 2) 北京空间科技信息研究所, 北京 100086

✉ 通信作者, E-mail: shoubing_qi@163.com

摘要 对单张合成孔径雷达(SAR)欺骗干扰模板进行样本增广, 生成高质量的 SAR 欺骗干扰模板库, 有助于进行快速有效的 SAR 欺骗干扰。目前 SAR 欺骗干扰模板的样本增广方案由于缺乏相干斑噪声, 导致生成模板的真实性较低, 同时生成的模板图像与原图相似性较低。针对该问题, 本文提出了一种基于生成对抗网络的样本增广方案, 在网络中考虑了相干斑噪声的影响, 并使用注意力机制模块、残差密集模块、多尺度模块来提高网络对特征的提取能力。在 MSTAR 数据集上的实验表明, 本方案生成的图像具有与原始图像更加相似的图像特征, 并且含有相似的相干斑噪声特征, 具有更高的真实性, 由此验证了方法的有效性。

关键词 生成对抗网络; 合成孔径雷达; 图像样本增广; 相干斑噪声; 欺骗干扰图像

分类号 TN959

Research on Single SAR Deception Jamming Template Augmentation Scheme Based on Generative Adversarial Networks

LI Guiqiang¹, LANG Shinan¹, QI Shoubing²✉

1) School of Information Science and Technology, Beijing University of Technology, Beijing 100124, China

2) Beijing Institute of Space Science and Technology Information, Beijing 100086, China

✉ Corresponding author, E-mail: shoubing_qi@163.com

ABSTRACT To realize fast and effective synthetic aperture radar (SAR) deception jamming, it is essential to generate a high-quality library of SAR deception jamming templates, which can be achieved through sample augmentation on SAR deception jamming templates. Sample augmentation refers to the process of creating new, artificially generated templates by applying various techniques to existing SAR templates, thus expanding the available data and improving the robustness of the jamming process. However, the current schemes for sample augmentation of SAR deception jamming templates face several challenges. One of the main issues is that the authenticity of the generated templates is low because they lack realistic speckle noise, which is a natural feature in SAR images. Speckle noise is typically caused by random interference in the radar signal and is an inherent characteristic of SAR imagery. Without this noise, the generated templates fail to convincingly mimic real SAR data. Another issue is that the generated templates often exhibit low similarity to the target and shadow areas in the input templates. The target and shadow regions are crucial for SAR jamming since they contribute to the overall realism of the jamming effect. Low similarity in these regions can reduce the effectiveness of the jamming and make it easier for the enemy to detect the deception. To address these challenges, this study proposed an advanced sample augmentation scheme

收稿日期:

基金项目: 中国电波传播研究所稳定支持科研经费资助项目 (No. A132003W02)

地址: 北京市海淀区学院路 30 号

E-mail: xuebaozr@ustb.edu.cn

邮政编码: 100083

http://cje.ustb.edu.cn

电话: 010-62333436

based on generative adversarial networks (GANs), which has the capability to generate high-quality SAR deception jamming templates with realistic shadows. GANs are a class of deep learning models known for their ability to generate new data by learning from existing data, making them well-suited for sample augmentation tasks. The proposed scheme tackles the two main issues in the following ways. First, the influence of speckle noise was incorporated into the network architecture, enabling the model to generate images that closely resemble real SAR imagery. This inclusion of speckle noise prevents the problem of low authenticity in the generated templates and enhances their realism. Second, a channel attention mechanism module was introduced into the GAN architecture to improve the model's ability to focus on and learn shadow features. Shadows play a vital role in the structure and appearance of SAR images, and the attention mechanism ensures that the model pays more attention to the shadow areas during the learning process. As a result, the generated templates exhibit a higher similarity to the target and shadow areas in the input templates, improving the quality of the augmented samples. To evaluate the performance of the proposed scheme, a comprehensive comparison was made between the SinGAN, which is a generative adversarial network designed for image sample augmentation of a single SAR image, the denoising diffusion probabilistic models (DDPM), which are generative models that reverse a gradual noising process to generate high-quality samples, and the proposed scheme. The evaluation was based on three key metrics: the equivalent number of looks (ENL), correlation coefficient (CC), and the gradient-based structural similarity (GSSIM) between the target and shadow regions in the augmented templates. These metrics were chosen to assess the quality, realism, and similarity of the generated templates. The comparison results demonstrated that the templates generated by the proposed scheme outperformed those generated by SinGAN and DDPM in terms of authenticity and similarity to the original target and shadow regions. Specifically, the proposed scheme was able to generate templates that more closely resembled the real SAR images, incorporating both the speckle noise and the shadow features effectively. These improvements make the proposed approach more suitable for achieving fast and effective SAR deception jamming, providing a powerful tool for enhancing the realism and effectiveness of SAR-based jamming operations.

KEY WORDS generative adversarial networks (GANs); synthetic aperture radar (SAR); image sample augmentation; speckle noise; images of deceptive jamming

合成孔径雷达 (SAR) 欺骗干扰技术可以有效地掩护我方重要的设施和设备^[1,2], 以及隐蔽特定的行动^[3,4], 且具有功率需求低的优点, 是 SAR 干扰技术的热门研究课题^[5-7]。SAR 欺骗干扰通过截获 SAR 系统发射的信号, 根据 SAR 欺骗干扰模板对其进行调制, 使其包含虚假目标或场景的欺骗干扰信息, 然后向 SAR 系统进行转发, 从而达到欺骗干扰的目的。目前, SAR 欺骗干扰模板产生的方法包括使用 SAR 欺骗干扰模板库和电磁散射模型两类。在现有技术之间, 使用 SAR 欺骗干扰模板库比使用电磁散射模型进行欺骗干扰花费更少的时间和人力, 这进一步促进了欺骗干扰在实际场景中的快速使用。在欺骗干扰中使用 SAR 欺骗干扰模板库的效果取决于欺骗干扰模板的细化程度^[8-10]。然而, 真实性较低的欺骗干扰模板很容易被敌方识别出来, 从而降低了欺骗干扰的有效性。

目前针对 SAR 欺骗干扰模板的样本增广方案有两类: 第一类是通过平移、旋转、缩放等传统方案得到增广的 SAR 欺骗干扰模板库, 这类方案并未从根本上改变图像内部的信息, 只是在图像目标的几何层面进行了形状的改变, 而处理后的部分目标会失去真实的对应关系, 对欺骗干扰的使用具有很大的局限性; 第二类是通过深度学习的方案进行图像样本增广, 即使用深度学习模型能够有效地捕捉 SAR 欺骗干扰模板中复杂的数据分布和特征, 使其能够生成较为逼真、多样化的 SAR 欺骗干扰模板。在深度学习方案中, 有两类方法: 使用单张模板生成和使用数据集生成。由于单张模板更容易获得, 使用单张模板在可用性方面更有优势^[11-12]。

然而以上两类方案没有考虑 SAR 固有的相干斑噪声的影响导致欺骗干扰模板的真实性显著降

低，同时输入模板与真实图像的相似性也较低。因此，需要结合 SAR 图像相干斑噪声特征，针对单张 SAR 欺骗干扰模板，设计一种快速、准确的样本增广网络，使得能够在短时间内获得适用性更强、更加多样化且真实性较高的 SAR 欺骗干扰模板库。

1 输入特征分析

在本方案的生成对抗网络的训练过程中，需要输入一张 SAR 欺骗干扰模板图像。该网络根据输入图像模板的相干斑噪声特性，对 SAR 欺骗干扰模板进行图像样本增广。

相干斑噪声是在 SAR 成像过程中由于不同回波相位之间的相互作用导致 SAR 图像上出现的颗粒状斑点，是 SAR 图像的一种固有特性。相干斑噪声是 SAR 图像中的乘性噪声，所以 SAR 图像的随机分布可用数学模型可表示为^[13]：

$$I(x, y) = A(x, y) \times Z(x, y) \quad (1)$$

式中， x, y 分别表示图像的横坐标和纵坐标， $I(x, y)$ 表示 SAR 图像的观测值， $A(x, y)$ 表示未受到相干斑为污染的理想图像， $Z(x, y)$ 则表示在 SAR 系统成像时生成的相干斑噪声。带阴影的 SAR 欺骗干扰模板的相干斑噪声幅度服从瑞利分布，如式(2)所示，其中 σ^2 为方差。

$$P(Z(x, y)) = \frac{Z(x, y)}{\sigma^2} e^{-\frac{Z(x, y)^2}{2\sigma^2}} \quad (2)$$

鉴于 SAR 正侧视的成像的特性，一些目标区域可能会由于遮挡而无法被雷达照射到，从而无法产生回波，使得接收机在收到回波信号进行成像处理后，无法被雷达照射到的区域在图像域中表现出是暗色区域，即为目标的阴影^[14-15]。由于阴影区域未被雷达照射到，因此雷达接收机无法接收到该区域的回波信号，从而导致在 SAR 欺骗干扰图像中，阴影区域不包含相干斑噪声。考虑到阴影区域的特性，其像素强度值应为整个图像区域的最小值。因此，通过寻找图像中平均强度最低的子区域，可以确定阴影区域的位置。在 SAR 欺骗干扰模板中，用一个大小为 $(2C+1)^2$ 的滑动窗口在图像内移动，计算各个窗口内的平均强度值，阴影点 (x_s, y_s) 则为平均值最小的子区域中心点，即：

$$(x_s, y_s) = \arg \min_{C < x \leq B-C, C < y \leq B-C} \left(\sum_{i=x-C}^{x+C} \sum_{j=y-C}^{y+C} I(i, j) / (2C+1)^2 \right) \quad (3)$$

其中， B 为图像边长。则阴影区域 I_s 可表示为：

$$I_s = \{I(x, y) | x = x_s, y = y_s\} \quad (4)$$

2 输入特征分析

2.1 方案概述

为了实现对 SAR 欺骗干扰模板快速、真实的样本增广，需要针对该模板的相干斑噪声特征，设计相应的生成对抗网络，使生成的 SAR 欺骗干扰模板库中的图像与输入的 SAR 欺骗干扰模板具有高度的相似性和准确性。由于相干斑噪声是 SAR 图像固有的噪声，为了使生成的 SAR 欺骗干扰模板更加具有欺骗性，需要模拟出相干斑噪声并作为噪声输入之一，经过生成对抗网络的处理，相干斑噪声会在生成的 SAR 欺骗干扰模板中得到保留；另外，SAR 欺骗干扰模板中，背景的亮度通常为稍浅的暗色区域，与阴影区域亮度差异较小，使生成对抗网络较难学习到阴影的特征，因此需要针对阴影特征的提取能力进行增强。所提方案的具体工作流程如下：

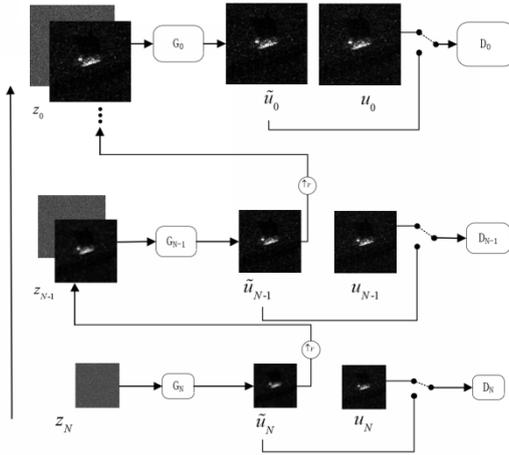


图 1 网络结构图

Fig.1 Structure of the network

本方案采用了金字塔式的多尺度结构，以全面捕获 SAR 欺骗干扰模板的全局信息以及 SAR 欺骗干扰模板的细节特征。每个金字塔层级都含有一个生成对抗网络 (GAN)，专门用于生成和判别当前尺度下的 SAR 欺骗干扰模板，具体的网络结构如图 1 所示。本方案只需要获取单一 SAR 欺骗干扰模板在不同尺度下的结构数据，自动生成网络的训练集。

图 1 中的金字塔的尺度为 N ，该尺度由输入的 SAR 欺骗干扰模板的大小决定。原始输入的 SAR 欺骗干扰模板在不同尺度下的下采样结果为 $\{u_N, u_{N-1}, \dots, u_0\}$ ，采样因子为 r^n ，其中 $n \in \{0, 1, 2, \dots, N\}$ ，且 $r > 1$ 。金字塔模型从最粗的尺度开始训练，第一个生成器 G_N 能够根据输入的高斯白噪声 z_g 与相干斑噪声 z_s 得到混合后的噪声，生成增广样本，该过程可表示为：

$$\tilde{u}_N = G_N(z_N) \quad (5)$$

通过混合噪声 z_N 生成样本 \tilde{u}_N 后，将 \tilde{u}_N 上采样的结果与高斯白噪声同时输入下一个尺度的生成器 G_{N-1} 中，再由生成器 G_{N-1} 生成新的样本 \tilde{u}_{N-1} ，以此类推，每一个尺度生成器的输出可表示为：

$$\tilde{u}_{n-1} = G_{n-1}[z_{n-1}, (\tilde{u}_n)^{\uparrow r}], n < N+1 \quad (6)$$

式中， \tilde{u}_{n-1} 为第 $n-1$ 个尺度下生成器的输出， G_{n-1} 为该尺度下的生成器， z_{n-1} 为该尺度下输入的混合噪声， $(\tilde{u}_n)^{\uparrow r}$ 为第 n 个尺度下生成器输出 \tilde{u}_n 的上采样。

将第 n 个尺度下输入的噪声 z_n 和第 $n+1$ 个尺度下生成器输出 \tilde{u}_{n+1} 的上采样结果同时输入生成器，生成器的主要作用是生成 \tilde{u}_{n+1} 缺少的细节并加入到 \tilde{u}_{n+1} 中，生成新的 SAR 欺骗干扰模板样本 \tilde{u}_n ，可表示为：

$$\tilde{u}_n = (\tilde{u}_{n+1})^{\uparrow r} + f_n[z_n + (\tilde{u}_{n+1})^{\uparrow r}] \quad (7)$$

式中， f_n 为从第 $n+1$ 个尺度下生成器输出 \tilde{u}_{n+1} 的上采样 $(\tilde{u}_{n+1})^{\uparrow r}$ 和噪声 z_n 到生成细节的映射，每一尺度的生成器具有相似的结构。整个训练过程是从下往上进行的，由粗到细，逐步进行。在每一尺度上，生成器 G_n 的输出 \tilde{u}_n 传递给判别器 D_n ，同时也输入到下一层的生成器中。判别器 D_n 通过对当前尺度输入的 SAR 欺骗干扰模板 u_n 经过下采样得到的数据块，与第 n 个尺度下生成器输出 \tilde{u}_n 进行对比，判别模板图像的“真假”，当判别器 D_n 无法判别真假时，再进入下一金字塔层。其中，SAR 欺骗干扰模板 u_n 由三种不同特征的区域组成，分别为目标区域 I_t 、阴影区域 I_s 和背景区域 I_b ，如公式 (8) 所示。目标区域 I_t 内部明亮细节信息复杂，具有规则的形状；而

阴影区域 I_s 内部为暗色区域，内部较为纯净；背景区域 I_b 通常较暗，纹理细节明显，没有明显的几何形状，从而更容易被网络学习。

$$u_n = I_t + I_s + I_b \quad (8)$$

2.2 方案设计

2.2.1 生成器结构

生成器 G_N 的输入在原有高斯白噪声 z_g 的基础上，加入了相干斑噪声 z_s 作为混合噪声输入。在由卷积层、批量归一化和带泄露修正线性单元组成的 5 个全卷积网络之间，加入了区域注意力机制模块^[16]，用来提高对目标的学习能力，在图像区域层面，使网络捕获特征图中的高响应区域，从而使模型更加关注特征图的阴影对应的区域 I_s ，并对阴影特征区域 I_s 进行处理。由于目标与其阴影在学习过程中重要性更强，且阴影特征较难被准确提取，所以在生成过程中更需要关注阴影部分，加入注意力机制能够提高网络对 SAR 欺骗干扰模板 u_n 中阴影区域 I_s 形状轮廓特征的提取能力；将多尺度模块^[17]置于生成器 G_N 前侧，能够对 SAR 目标从轮廓形状到内部细节进行更细致地提取，提高生成样本的真实性。同时也能减少冗余信息、加快收敛速度；带有注意力机制的残差密集模块^[18]能够充分使用各个层级的卷积所提取的特征，进一步提高特征提取能力，并且能够防止因网络过深而出现梯度消失的现象，提高网络的稳定性。生成器 G_N 的结构如图 2 所示。

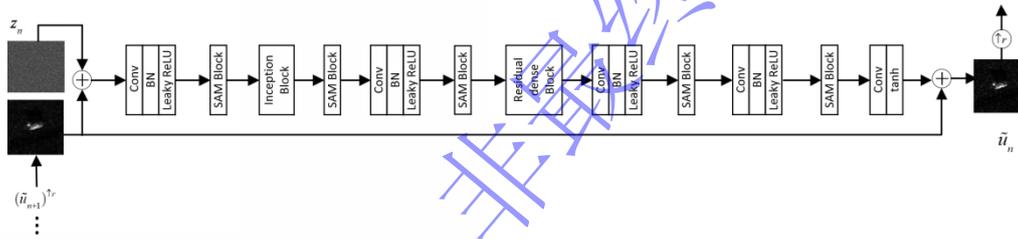


图 2 生成器结构图

Fig.2 Block diagram of the generator

2.2.2 判别器结构

判别器 D_n 采用马尔科夫判别器(patch-GAN)思想^[19]，由 5 个全卷积层构成，采用下采样方案捕捉当前尺度下数据的分布，如图 3 所示。输入 SAR 欺骗干扰模板 u_n 和生成的 SAR 欺骗干扰模板 \tilde{u}_n 。全卷积网络负责学习该尺度下输入的两张 SAR 欺骗干扰模板数据的内部分布信息，计算二者的损失函数以鉴别同尺度下生成的 SAR 欺骗干扰模板 \tilde{u}_n 真假。在生成器 G_N 和判别器 D_n 的对抗博弈过程中，生成的 SAR 欺骗干扰模板越来越逼真。将当前尺度生成的 SAR 欺骗干扰模板和下采样得到的 SAR 欺骗干扰模板进行对比，并计算损失函数。

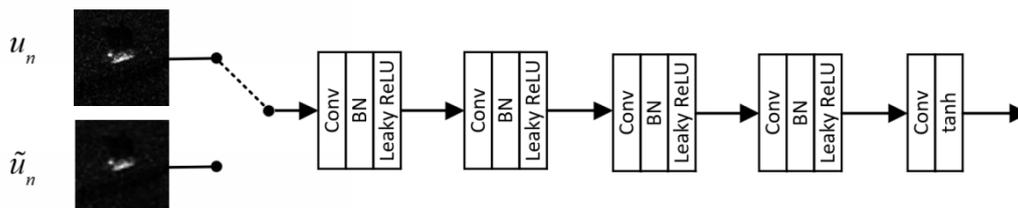


图 3 判别器结构图

Fig.3 Structural diagram of the discriminator

2.2.3 损失函数

模型训练从最粗的尺度开始，按图 3 所示的多尺度结构训练，每训练一个尺度，该尺度的 GAN 就会被固定。

对抗损失 $S_{\text{loss_adv}}$ 可表示为：

$$S_{\text{loss_adv}} = \text{adv}\{E_{u_n \sim p_{\text{data}}}[D(u_n)] + E_{\tilde{u}_n \sim p_g}[D(\tilde{u}_n)]\} + \lambda E_{\hat{u} \sim p_{\hat{u}}}[\|\nabla D(\hat{u})\| - 1]^2 \quad (9)$$

公式中， adv 为取平均值函数， p_{data} 为输入的带阴影的 SAR 欺骗干扰模板的分布， p_g 为生成的带阴影的 SAR 欺骗干扰模板的分布， $u_n \sim p_{\text{data}}$ 表示 u_n 服从 p_{data} 分布， $\tilde{u}_n \sim p_g$ 表示 \tilde{u}_n 服从 p_g 分布， u_{data} 为真实样本的集中区域， u_g 为生成样本的集中区域， \hat{u} 在真实样本集中区域 u_{data} 和生成样本集中区域 u_g 中随机插值， $\hat{u} = \varepsilon u_{\text{data}} + (1 - \varepsilon)u_g, \varepsilon \in [0, 1]$ ， $\hat{u} \sim p_{\hat{u}}$ 表示 \hat{u} 服从 $p_{\hat{u}}$ 分布。 $D(u_n)$ 为判别器判别输入的 SAR 欺骗干扰模板时输出的结果， $D(\tilde{u}_n)$ 为判别器判别生成的 SAR 欺骗干扰模板时输出的结果。 E 为期望， ∇ 为梯度算符， $\|\cdot\|$ 为 L1 范数， λ 为梯度损失函数的权重。

重建损失 $S_{\text{loss_rec}}$ 可表示为：

$$S_{\text{loss_rec}} = \|G_n(0, [\tilde{u}_n^{\text{rec}} \uparrow^r]) - u_n\|^2 \quad (10)$$

\tilde{u}_n^{rec} 为用噪声图谱在第 n 个尺度生成的模板图像。

第 n 个 GAN 的训练损失 $S_{\text{loss_train}}$ 可以根据对抗损失 $S_{\text{loss_adv}}$ 和重建损失 $S_{\text{loss_rec}}$ 共同得到，可表示为：

$$S_{\text{loss_train}} = \min_{G_n} \max_{D_n} S_{\text{loss_adv}}(G_n, D_n) + \alpha S_{\text{loss_rec}}(G_n) \quad (11)$$

式中， α 为重建损失在训练损失中所占的权重。

3 实验结果与分析

3.1 实验数据介绍

实验数据使用来自 MSTAR 数据集的图像^[20]。MSTAR 数据集是由桑迪亚国家实验室 SAR 传感器平台采集，使用 X 波段 SAR 传感器在 0.3m 分辨率聚光灯模式下收集。公开可用的 MSTAR 数据集包含十种不同类别的地面目标，即装甲车(BMP-2、BRDM-2、BTR-60 和 BTR-70)、坦克(T-62、T-72)、火箭发射器(2S1)、防空部队(ZSU-234)、卡车(ZIL-131)和推土机(D7)。此外，MSTAR 数据集覆盖了不同仰角和方向，已被广泛用于合成孔径雷达自动目标识别算法的测试和性能比较。

3.2 增广图像质量评估指标

本文为更好地评估生成的 SAR 欺骗干扰模板库的质量，需要对其目标以及相干斑噪声进行评估。

等效视数 (equivalent numbers of looks, ENL) 用于衡量 SAR 图像中相干斑噪声的相对强度^[21-23]。较低的 ENL 值表示图像中存在较多的相干斑噪声。ENL 的计算公式如下:

$$\text{ENL} = \left(\frac{\mu}{\sigma} \right)^2 \quad (12)$$

式中, μ 为 SAR 图像的均值, σ 为 SAR 图像的标准差。对各图的红色方框区域计算等效视数。相关系数 (correlation coefficient, CC) 描述了两个图像之间的统计相关性。两幅图像越相似, 相关系数就越大。对于大小为 $V \times W$ 的原始图像 u_n 和生成的图像 \tilde{u}_n , 相关系数可以定义如下:

$$\text{CC}(u_n, \tilde{u}_n) = \frac{\sum_{y=1}^W \sum_{x=1}^V (u_n(x, y) - \mu_{u_n}) \cdot (\tilde{u}_n(x, y) - \mu_{\tilde{u}_n})}{\sqrt{\sum_{y=1}^W \sum_{x=1}^V (u_n(x, y) - \mu_{u_n})^2 \cdot \sum_{y=1}^W \sum_{x=1}^V (\tilde{u}_n(x, y) - \mu_{\tilde{u}_n})^2}} \quad (13)$$

其中 μ_{u_n} 和 $\mu_{\tilde{u}_n}$ 分别为 u_n 和 \tilde{u}_n 的均值。

基于梯度的结构相似性 (gradient-based structural similarity, GSSIM) 结合了图像中的亮度、对比度和基于梯度的结构信息, 可以定义如下^[24]:

$$\text{GSSIM}(u_n, \tilde{u}_n) = [l(u_n, \tilde{u}_n)]^\delta [c(u_n, \tilde{u}_n)]^\beta [g(u_n, \tilde{u}_n)]^\gamma \quad (14)$$

其中:

$$l(u_n, \tilde{u}_n) = \frac{2\mu_{u_n}\mu_{\tilde{u}_n} + k_1}{\mu_{u_n}^2 + \mu_{\tilde{u}_n}^2 + k_1} \quad (15)$$

$$c(u_n, \tilde{u}_n) = \frac{2\sigma_{u_n}\sigma_{\tilde{u}_n} + k_2}{\sigma_{u_n}^2 + \sigma_{\tilde{u}_n}^2 + k_2} \quad (16)$$

$$g(u_n, \tilde{u}_n) = \frac{2\sum_y \sum_x G_{u_n}(x, y)G_{\tilde{u}_n}(x, y) + k_3}{\sum_y \sum_x [G_{u_n}(x, y)]^2 + \sum_y \sum_x [G_{\tilde{u}_n}(x, y)]^2 + k_3} \quad (17)$$

式中, σ_{u_n} 和 $\sigma_{\tilde{u}_n}$ 分别为图像 u_n 、 \tilde{u}_n 的标准差; $G_{u_n}(x, y)$ 和 $G_{\tilde{u}_n}(x, y)$ 分别表示 u_n 和 \tilde{u}_n 的行和列中的像素的梯度值; k_1 、 k_2 和 k_3 是防止分母为零的常数。参数 δ 、 β 、 γ 大于零。GSSIM 值越高, 相似性就越高。

3.3 实验验证与分析

实验参数设置如下。实验输入为 MSTAR 数据集中对应的目标图像, 即 T72 和 ZIL-131 的 SAR 图像, 最粗糙尺度图像大小设置为 26 像素 \times 26 像素, 金字塔尺度数量设置为 8, 采样尺度因子为 1.27, 每个尺度的训练次数为 2000, 生成器和判别器的初始学习率取 0.0005, 参数更新方法采用自适应矩估计算法, 一阶矩估计的指数衰减率取 0.5。实验的开发环境为 Python 3.7, 采用的显卡为 NVIDIA GeForce GTX 1060, 显存 6 GB。

3.3.1 T72 坦克卡车模板样本增广实验

本方案所述的生成对抗网络的主要目标是提取目标的多层次特征, 并生成高质量的 SAR 欺骗干扰模板, 使该模板与输入的 T72 坦克模板具有高度相似性和真实性。图 4 显示了本网络生成的

T72 坦克欺骗干扰模板与真实带阴影的 T72 坦克欺骗干扰模板的对比。

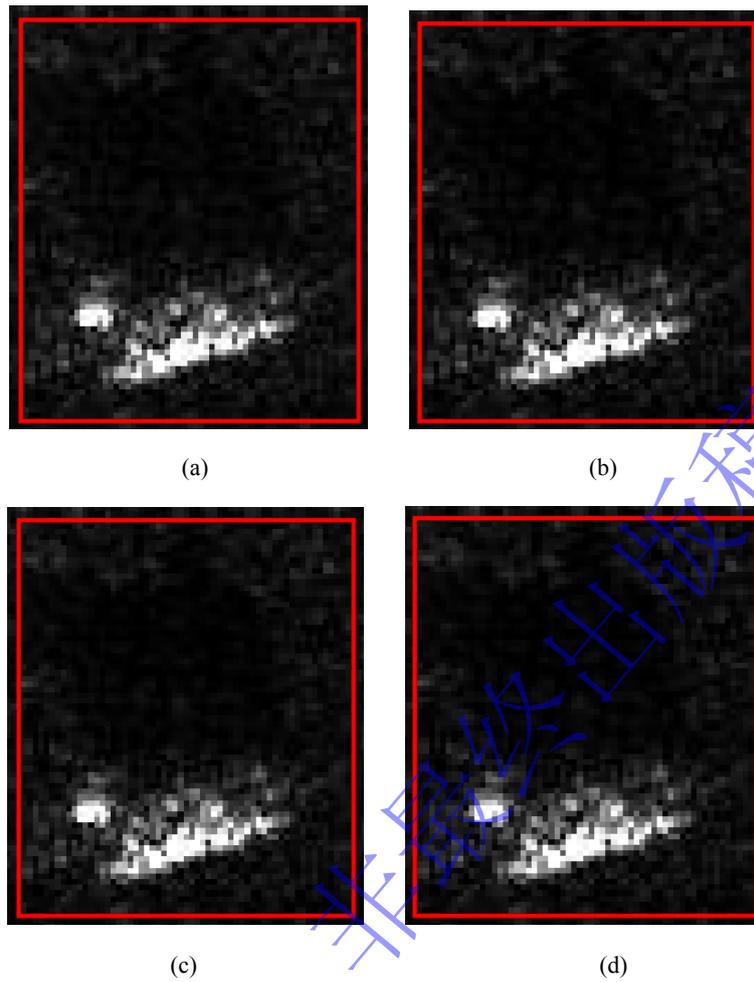


图 4 真实图像和 3 张生成的欺骗干扰模板样本对比。(a)真实图像;(b)欺骗干扰模板 1;(c)欺骗干扰模板 2;(d)欺骗干扰模板 3

Fig.4 Real image and three generated samples. (a)real image; (b)generated sample 1; (c)generated sample 2; (d)generated sample 3

从生成的带阴影的 T72 坦克 SAR 欺骗干扰模板能够看出，图中含有较为明显的相干斑噪声的特征，具有较高的真实性。T72 坦克的阴影轮廓真实且清晰，T72 坦克边缘与目标的内部细节也得到了很好的体现。通过对真实带阴影的 T72 坦克欺骗干扰模板和生成的带阴影的 T72 坦克欺骗干扰模板的对比，能够直观地看出，本网络生成的带阴影的 T72 坦克欺骗干扰模板具有较高的真实性。

图 4 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 1 所示。

表 1 本方案图像评价指标对比

Table 1 Comparison of images evaluation indicators of this scheme

Image	ENL	GSSIM	CC
Figure.4(a)	2.5604	—	—
Figure. 4(b)	1.9764	0.9518	0.9964
Figure.4(c)	1.9090	0.9516	0.9963
Figure.4(d)	1.9092	0.9546	0.9967
Average	1.9315	0.9527	0.9965
Similarity	0.7544	0.9527	0.9965

表 1 显示，图 4(a)所示的原始图像的 ENL 值为 2.5604。生成的 SAR 欺骗干扰模板的 ENL 值分别为 1.9764、1.9090 和 1.9092，平均值为 1.9315。因此，生成模板的 ENL 值与原始图像之间的差异很小，图像之间的高相似性为 75.44%（两张图像之间的等效视数的比值）。这一结果表明，生成的 SAR 欺骗干扰模板具有较高的真实性。

对于原始图像和生成的 SAR 欺骗干扰模板，计算目标和阴影区域的 GSSIM 和 CC 的值。原始图像和生成的模板的目标和阴影区域的 GSSIM 值分别为 0.9518、0.9516 和 0.9546，平均值为 0.9527，这表明生成的模板和原始图像之间具有 95.27%的梯度结构相似性（两张图像之间 GSSIM 的比值）。原始图像和生成模板的目标和阴影区域的相关系数分别为 0.9964、0.9963 和 0.9967，平均值为 0.9965，表明生成模板和原始图像之间具有 99.65%的高度相似性（两张图像之间相关系数的比值）。因此，本方案生成的具有阴影的 SAR 欺骗干扰模板，与原始图像具有很高的相似性和真实性。

3.3.2 ZIL-131 卡车模板样本增广实验

使用本方案对 ZIL-131 卡车的 SAR 图像进行样本增广，并计算评价指标。图 5 显示了真实带阴影的 ZIL-131 卡车欺骗干扰模板与本网络生成的 ZIL-131 卡车欺骗干扰模板的对比。

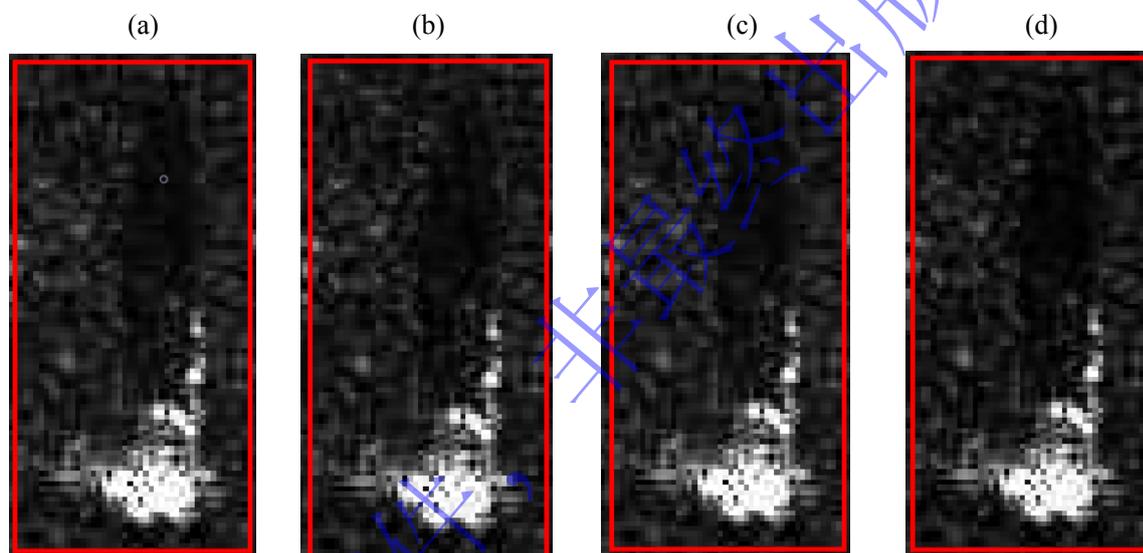


图 5 真实图像和 3 张生成的欺骗干扰模板样本对比。(a)真实图像;(b)欺骗干扰模板 1;(c)欺骗干扰模板 2;(d)欺骗干扰模板 3

Fig.5 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 5 所示的原图和 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 2 所示。

表 2 本方案图像评价指标对比

Table 2 Comparison of images evaluation indicators of this scheme

Image	ENL	GSSIM	CC
Figure.5(a)	3.0648	—	—
Figure.5(b)	2.8589	0.8562	0.9060
Figure.5(c)	2.4291	0.9117	0.9543
Figure.5(d)	2.3734	0.8200	0.9036
Average	2.5538	0.8626	0.9213
Similarity	0.8333	0.8626	0.9213

由表 2 可知，生成的模板与原始图像图 5(a)的 ENL 值、GSSIM 值和 CC 值的相似性分别为

0.8333、0.8626 和 0.9213，这表明生成的 SAR 欺骗干扰模板与原始图像具有高度的真实性，以及很高的纹理和结构相似性。

3.4 消融实验

首先，我们将输入到发生器 G_N 中的混合噪声替换为高斯噪声，并不改变其他条件的情况下进行了实验并得到结果。图 6 显示了 T72 坦克欺骗干扰模板与真实的 T72 坦克欺骗干扰模板的对比。

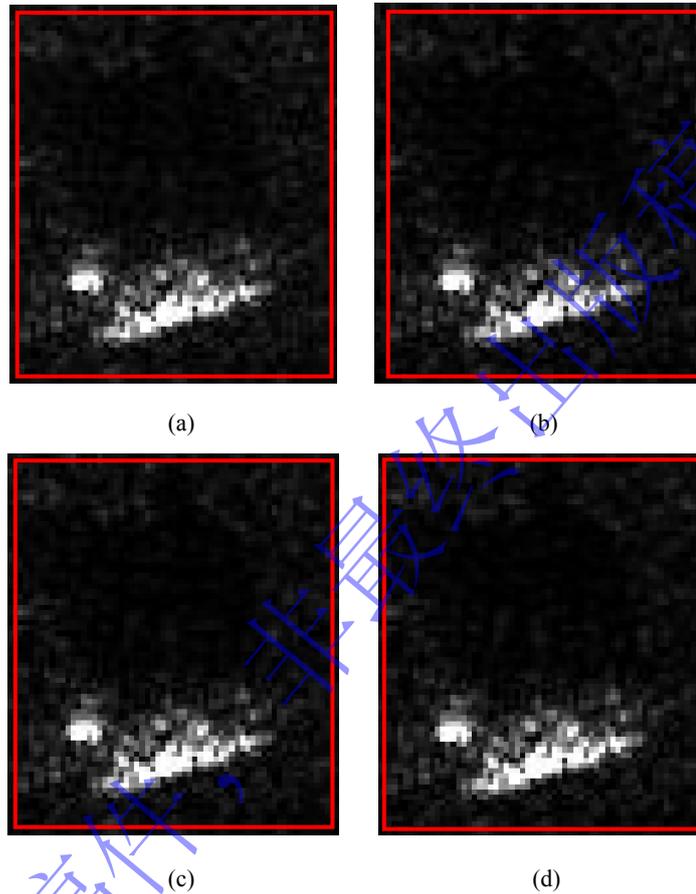


图 6 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.6 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 6 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 3 所示。

表 3 删除混合噪声只保留高斯噪声后图像评价指标对比

Table 3 Comparison of images evaluation indicators of SinGAN scheme

Image	ENL	GSSIM	CC
Figure.6(a)	2.5604	—	—
Figure.6(b)	1.6197	0.8681	0.9815
Figure.6(c)	1.6324	0.8652	0.9810
Figure.6(d)	1.6421	0.8620	0.9807
Average	1.6314	0.8651	0.9811
Similarity	0.6371	0.8651	0.9811

表 3 中的结果显示，生成的模板和原始图像之间的 GSSIM 和 CC 的相似度分别为 0.8651 和 0.9811，这表明生成的欺骗干扰模板与原始图像具有较高的纹理和结构相似性。然而，生成的模板和原始图像之间的 ENL 相似性为 0.6371，明显低于使用混合噪声作为输入得到的结果。使用混合噪声作为输入可以得到较高的 ENL 表明使用混合噪声作为输入可以提高生成的欺骗干扰模板的真实性。

第二，我们在不改变其他条件的情况下从生成器中删除了空间注意力机制模块，进行了实验并得到结果。图 7 显示了 T72 坦克欺骗干扰模板与真实的 T72 坦克欺骗干扰模板的对比。

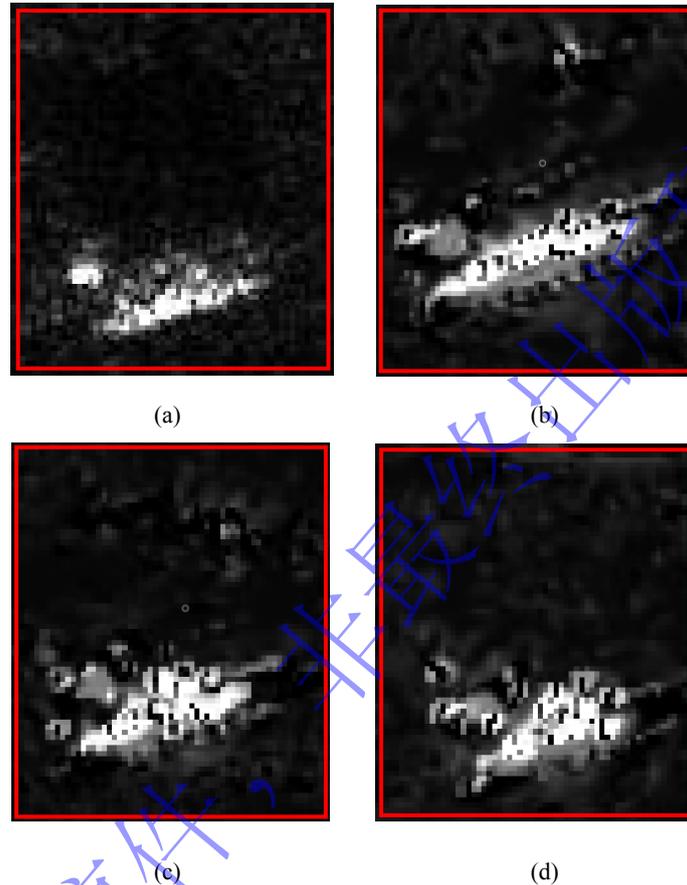


图 7 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.7 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 7 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 4 所示。

表 4 删除空间注意力模块后方案图像评价指标对比

Table 4 Comparison of images evaluation indicators of SinGAN scheme

Image	ENL	GSSIM	CC
Figure.6(a)	2.5604	—	—
Figure.6(b)	1.9169	0.5576	0.3571
Figure.6(c)	1.9301	0.5722	0.2373
Figure.6(d)	1.8258	0.5425	0.1951
Average	1.8909	0.5574	0.2632
Similarity	0.7385	0.5574	0.2632

表 4 中的结果显示，生成的模板和原始图像之间的 GSSIM 和 CC 的相似度分别为 0.5574 和 0.2632，这表明生成的欺骗干扰模板与原始图像的纹理和结构相似性较低。当空间注意力机制模块被移除时，图像中的目标具有不同的外观形状，无法识别为坦克的形状。这个结果表明空间注意力机制模块提高了网络对目标形状和他们影子的学习能力。

第三，我们在不改变其他条件的情况下从生成器中删除了多尺度模块，进行了实验并得到结果。图 8 显示了 T72 坦克欺骗干扰模板与真实的 T72 坦克欺骗干扰模板的对比。

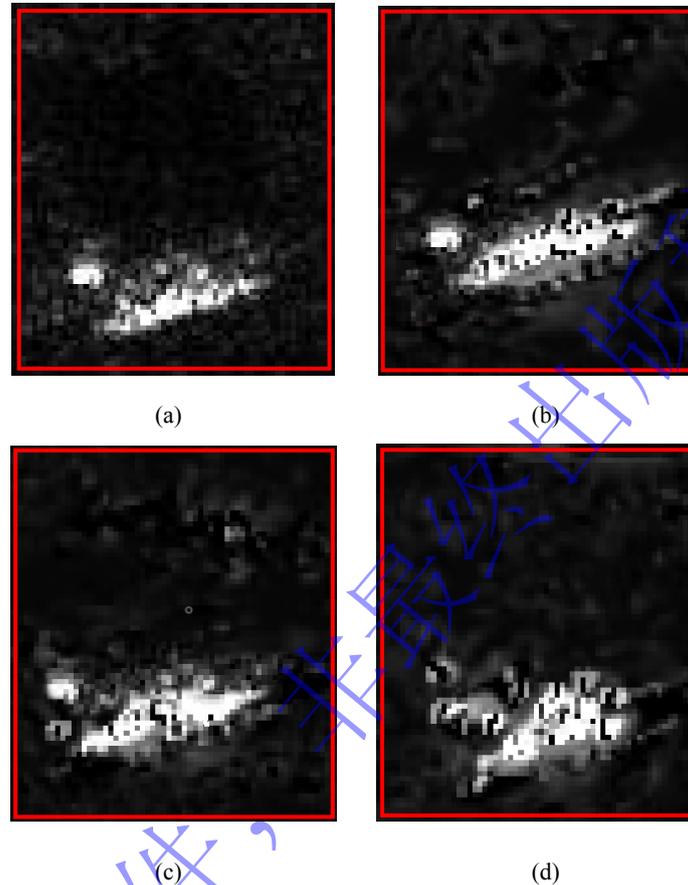


图 8 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.8 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 8 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 5 所示。

表 5 删除多尺度模块后图像评价指标对比

Table 5 Comparison of images evaluation indicators of SinGAN scheme

Image	ENL	GSSIM	CC
Figure.6(a)	2.5604	—	—
Figure.6(b)	1.9075	0.5523	0.3548
Figure.6(c)	1.9156	0.5425	0.2158
Figure.6(d)	1.8741	0.5217	0.1874
Average	1.8991	0.5388	0.2527
Similarity	0.7417	0.5388	0.2527

表 5 中的结果显示，生成的模板和原始图像之间的 GSSIM 和 CC 的相似度分别为 0.5388 和

0.2527, 这表明生成的欺骗干扰模板与原始图像的纹理和结构相似性较低。当多尺度模块被移除时, 图像中的目标具有不同的外观形状, 无法识别为坦克的形状。这个结果表明空间注意力机制模块提高了网络对目标形状和他们影子的学习能力。

第四, 我们在不改变其他条件的情况下从生成器中删除了残差密度模块, 进行了实验并得到结果。图 9 显示了 T72 坦克欺骗干扰模板与真实的 T72 坦克欺骗干扰模板的对比。

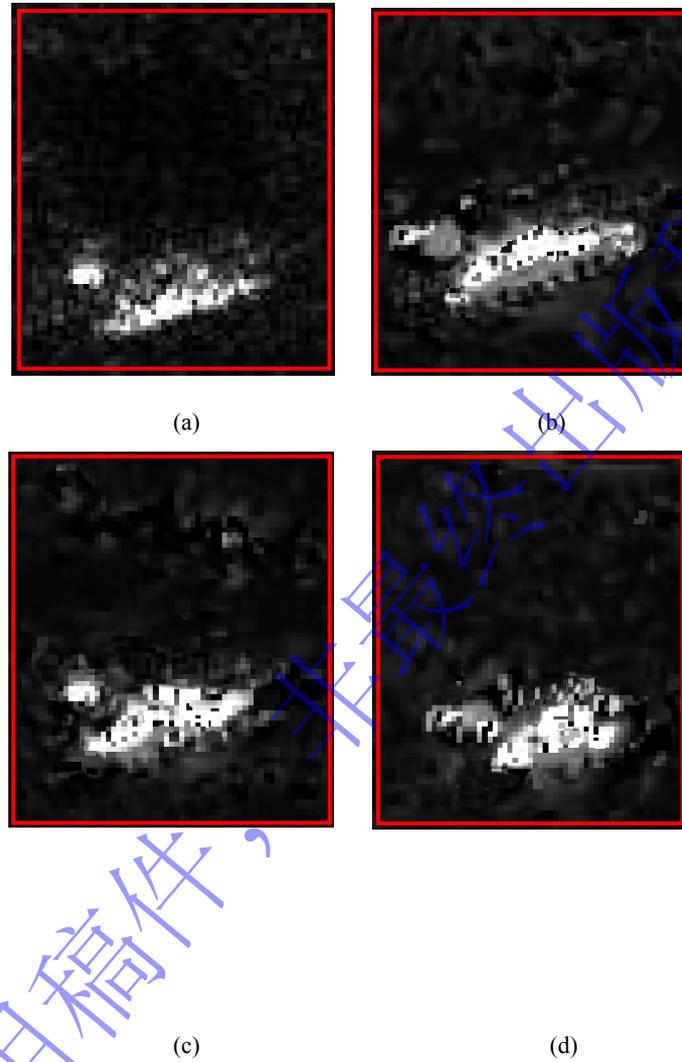


图 9 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.9 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 9 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 6 所示。

表 6 删除残差密度模块后图像评价指标对比

Table 6 Comparison of images evaluation indicators of SinGAN scheme

Image	ENL	GSSIM	CC
Figure.6(a)	2.5604	—	—
Figure.6(b)	1.9311	0.5486	0.3369
Figure.6(c)	1.9185	0.5356	0.2247

Figure.6(d)	1.7988	0.5145	0.1685
Average	1.8828	0.5329	0.2434
Similarity	0.7353	0.5329	0.2434

表 6 中的结果显示，生成的模板和原始图像之间的 GSSIM 和 CC 的相似度分别为 0.5329 和 0.2434，这表明生成的欺骗干扰模板与原始图像的纹理和结构相似性较低。当残差模块被移除时，图像中的目标具有不同的外观形状，无法识别为坦克的形状。这个结果表明空间注意力机制模块提高了网络对目标形状和他们影子的学习能力。

3.5 与其他方案对比分析

3.5.1 SinGAN 方案对 T72 模板样本增广实验

由于 SinGAN 是目前能够对阴影 SAR 欺骗干扰模板进行样本增强并获得良好结果的方法。图 10 显示了 SinGAN 网络生成的 T72 坦克欺骗干扰模板与真实的 T72 坦克欺骗干扰模板的对比。

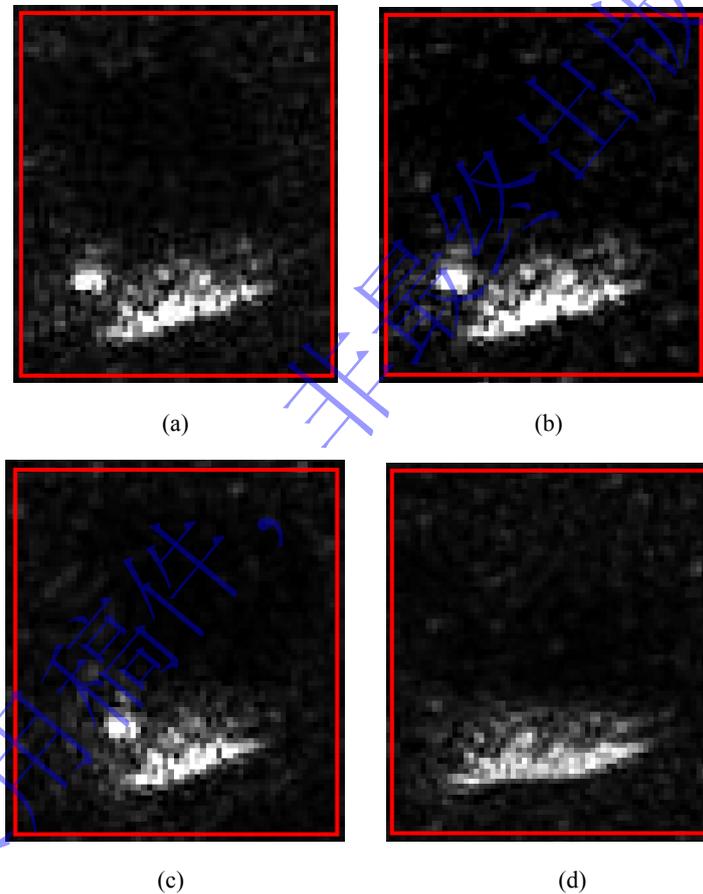


图 10 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.10 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 10 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 7 所示。

表 7 SinGAN 方案图像评价指标对比

Table 7 Comparison of images evaluation indicators of SinGAN scheme

Image	ENL	GSSIM	CC
-------	-----	-------	----

Figure.6(a)	2.5604	—	—
Figure.6(b)	1.6677	0.5998	0.6492
Figure.6(c)	1.7150	0.5710	0.6353
Figure.6(d)	0.5637	0.5514	0.8903
Average	1.3155	0.5741	0.7249
Similarity	0.5138	0.5741	0.7249

表 7 中的结果显示，图 10(a)所示原始图像的 ENL 为 2.5604，生成的带阴影的 SAR 欺骗干扰模板的 ENL 分别为 1.6677、1.7150 和 0.5637，平均值为 1.3155。生成的模板与原始图像的平均 ENL 的值存在显著差异，相似程度仅为 51.38%。这一结果表明，生成的模板比所提出的方法表现出较弱的相干斑噪声，导致真实性较差。

对于原始图像和生成的 SAR 欺骗干扰模板，计算目标和阴影区域的 GSSIM 和 CC 的值。原始图像和生成的模板的目标和阴影区域的 GSSIM 值分别为 0.5998、0.5710 和 0.5514，平均值为 0.5741，表明生成的模板和原始图像之间的梯度结构相似性较低，仅为 57.41%。原始图像和生成模板图像的目标和阴影区域的相关系数分别为 0.6492、0.6353 和 0.8903，平均值为 0.7249，说明生成的模板和原始图像之间的相似度较低，为 72.49%。因此，SinGAN 方案生成的具有阴影的 SAR 欺骗干扰模板与原始图像的相似度较低，真实性较差。

3.5.2 DDPM 方案对 T72 模板样本增广实验

Denoising Diffusion Probabilistic Models (DDPM) [25-26] 是一种基于参数化的马尔可夫链的模型，它使用变分推理进行训练，以在有限时间内生成与数据匹配的样本。这种模型通过正扩散过程逐渐向样本中添加噪声，直到信号完全破坏，然后通过逆扩散过程逐步从噪声生成数据。

使用 DDPM 方案对 T72 卡车图像进行第二组对比实验。图 11 显示了真实的 T72 卡车欺骗干扰图像与 DDPM 网络生成的 T72 卡车欺骗干扰模板的对比。

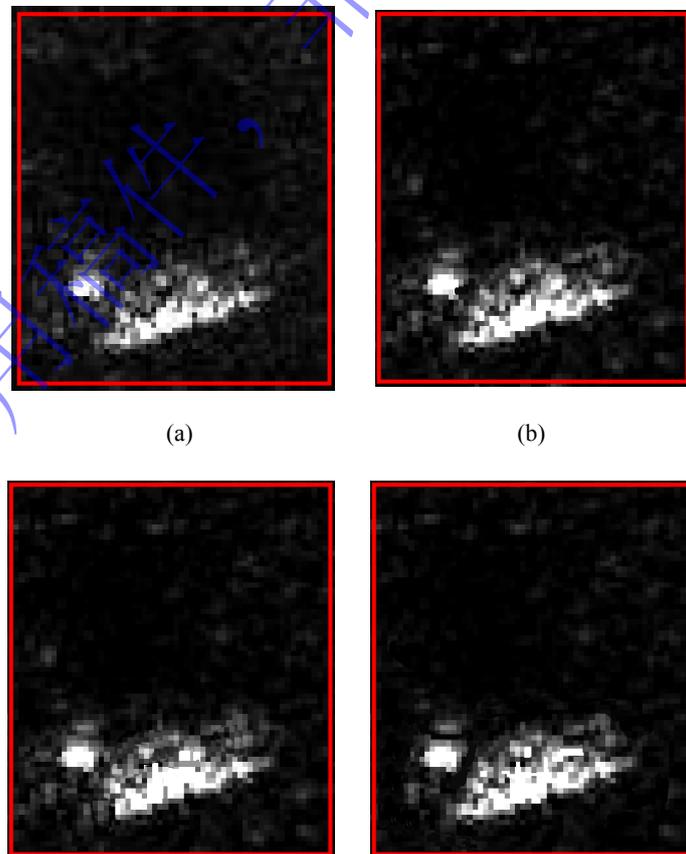


图 11 真实图像和 3 张生成的欺骗干扰模板样对比。(a)真实图像;(b)欺骗干扰模板 1;(c) 欺骗干扰模板 2;(d) 欺骗干扰模板 3

Fig.11 Real image and three generated samples. (a) real image; (b) generated sample 1; (c) generated sample 2; (d) generated sample 3

图 11 所示的原图与 3 张生成的 SAR 欺骗干扰模板的质量评估结果如表 8 所示。

表 8 DDPM 方案图像评价指标对比

Table 8 Comparison of images evaluation indicators of DDPM scheme

Image	ENL	GSSIM	CC
Figure. 7(a)	2.5604	—	—
Figure. 7(b)	1.5175	0.9501	0.9814
Figure. 7(c)	1.6091	0.9125	0.9628
Figure. 7(d)	1.5786	0.8897	0.9542
Average	1.5684	0.9174	0.9661
Similarity	0.6126	0.9174	0.9661

由表 8 的结果可以看出,生成的模板与原始图像图 11(a)的 ENL 值、GSSIM 值和 CC 值的相似性分别为 0.6126、0.9174 和 0.9661,这表明生成的 SAR 欺骗干扰模板与原始图片的结构和形状很相似,但是其相似性也低于本方案生成的模板的相似性:0.9527 和 0.9965。而且,DDPM 生成的模板与原始图像 ENL 值相似性为 0.6126,明显低于本方案生成的模板的 ENL 值相似性:0.7544。这表明本方案生成的欺骗干扰模板在真实性方面优于 DDPM 生成的欺骗干扰模板。

4 结 语

为了实现快速且有效的 SAR 欺骗干扰,需要通过对 SAR 欺骗干扰模板进行样本增广,生成高质量的 SAR 欺骗干扰模板库。目前 SAR 欺骗干扰模板的样本增广方案存在以下问题:因缺少相干斑噪声而导致的模板真实性较低。因此,本文提出了一种基于生成对抗网络的样本增广方案,能够生成高质量的 SAR 欺骗干扰模板库。

本方案使用了金字塔式多尺度结构作为整体框架,捕捉 SAR 欺骗干扰模板内部的信息,每层金字塔都有一个 GAN 负责该尺度下 SAR 欺骗干扰模板样本的生成和判别;生成器中加入带有注意力机制的残差密集模块、多尺度模块以及注意力机制模块,提升网络对特征的学习能力;在生成器的输入端加入相干斑噪声,使生成的模板带有相干斑噪声的特征。判别器使用马尔可夫判别器,用来判别生成图像的质量,并计算损失函数以改进生成器和判别器,使生成的模板质量更高。

使用三个常用的评估指标对本方案的结果与 SinGAN 方案、DDPM 方案的结果进行比较,结果表明,与 SinGAN 方案和 DDPM 方案相比,本方案在目标、阴影和相干斑噪声特征方面与原始图像更相似,从而验证了所提出的生成 SAR 欺骗干扰模板的方法的有效性。

本方案在生成器中使用了多尺度模块 inception V2,在之后的研究中还需考虑使用更加复杂的 inception V3 模块,以提高计算速度。

参 考 文 献

- [1] Deng Y K, Zhang H, Fan H T, et al. Forthcoming development trend of spaceborne SAR technology for earth environment monitoring. *Chinese Space Science and Technology*, 2023, 43(2): 32.
(邓云凯,张衡,范怀涛,等.面向综合环境监测的星载 SAR 技术发展.中国空间科学技术,2023,43(2): 32)
- [2] Yi T Z, Kang L H, Yu X G, et al. Analysis of space borne SAR system video imaging capacity model based on

- frame rate. *Chinese Space Science and Technology*, 2023, 43(5): 132.
(易天柱, 康利鸿, 余晓刚, 等. 基于帧频的星载 SAR 系统视频成像能力分析. 中国空间科学技术, 2023, 43(5): 132)
- [3] Yang G Z, Yu J, Xiao C B, et al. Ship Wake Detection in SAR Images with Complex Backgrounds Using Morphological Component Analysis. *Journal of Computer-Aided Design & Computer Graphics*, 2016, 28(10): 1662.
(杨国铮, 禹晶, 肖创柏, 等. 基于形态成分分析的复杂背景 SAR 图像舰船尾迹检测. 计算机辅助设计与图形学学报, 2016, 28(10): 1662)
- [4] Ye X M, Zhang G F, Hu X G. Missile-Borne SAR Image Geometry Correction Algorithm Introduced Coordinate Mapping. *Journal of Computer-Aided Design & Computer Graphics*, 2015, 27(2): 201.
(叶晓明, 张国峰, 胡晓光. 引入坐标映射原理的弹载 SAR 图像几何校正算法. 计算机辅助设计与图形学学报, 2015, 27(2): 201)
- [5] Zhou F, Zhao B, Tao M, et al. A large scene deceptive jamming method for space-borne SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(8): 4486.
- [6] Wang H, Zhang S, Wang W Q, et al. Multi-scene deception jamming on SAR imaging with FDA antenna. *IEEE Access*, 2019, 8: 7058.
- [7] Sun Q, Shu T, Yu K B, et al. Efficient deceptive jamming method of static and moving targets against SAR. *IEEE Sensors Journal*, 2018, 18(9): 3610.
- [8] Tian T, Zhou F, Bai X, et al. A partitioned deceptive jamming method against TOPSAR. *IEEE Transactions on Aerospace and Electronic Systems*, 2019, 56(2): 1538.
- [9] Zhao B, Huang L, Li J, et al. Deceptive SAR jamming based on 1-bit sampling and time-varying thresholds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2018, 11(3): 939.
- [10] Zhao B, Huang L, Li J, et al. Target reconstruction from deceptively jammed single-channel SAR. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 56(1): 152.
- [11] Shaham T R, Dekel T, Michaeli T. Singan: Learning a generative model from a single natural image in *Proceedings of the IEEE/CVF international conference on computer vision*, Korea, 2019:4570.
- [12] Fan W, Zhou F, Zhang Z, et al. Deceptive jamming template synthesis for SAR based on generative adversarial nets. *Signal processing*, 2020, 172: 107528.
- [13] Mullissa A G, Marcos D, Tuia D, et al. DeSpeckNet: Generalizing deep learning-based SAR image despeckling. *IEEE Transactions on Geoscience and Remote Sensing*, 2020, 60: 1.
- [14] Tang X, Zhang X, Shi J, et al. SAR deception jamming target recognition based on the shadow feature in *Proceedings of the 2017 25th European Signal Processing Conference (EUSIPCO)*. Greece, 2017: 2491.
- [15] Papon S, Narayanan R M. Classification via the shadow region in SAR imagery. *IEEE Transactions on Aerospace and Electronic Systems*, 2012, 48(2): 969.
- [16] Zhu X, Cheng D, Zhang Z, et al. An empirical study of spatial attention mechanisms in deep networks in *Proceedings of the IEEE/CVF international conference on computer vision*. Korea, 2019:6688.
- [17] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision in *Proceedings of the IEEE conference on computer vision and pattern recognition*. USA, 2016:2818.
- [18] Zhang Y, Tian Y, Kong Y, et al. Residual dense network for image super-resolution in *Proceedings of the IEEE conference on computer vision and pattern recognition*. USA, 2018:2472.
- [19] Wang Y, Yan X, Guan D, et al. Cycle-snsrgan: Towards real-world image dehazing via cycle spectral normalized soft likelihood estimation patch gan. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(11): 20368.
- [20] Lin C, Peng F, Wang B H, et al. Research on PCA and KPCA self-fusion based MSTAR SAR automatic target recognition algorithm. *Journal of Electronic Science and Technology*, 2012, 10(4): 352.
- [21] Vespe M, Greidanus H. SAR image quality assessment and indicators for vessel and oil spill detection. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(11): 4726.
- [22] Tang Z, Yu C, Deng Y, et al. Evaluation of Deceptive Jamming Effect on SAR Based on Visual Consistency. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 12246.
- [23] Cui Y, Zhou G, Yang J, et al. Unsupervised estimation of the equivalent number of looks in SAR images. *IEEE Geoscience and remote sensing letters*, 2011, 8(4): 710.
- [24] Liu, Y.; Yue, H. The Temperature Vegetation Dryness Index (TVDI) Based on Bi-Parabolic NDVI-Ts Space and Gradient-Based Structural Similarity (GSSIM) for Long-Term Drought Assessment Across Shanxi Province. *Remote Sensing*. 2018, 10:959.
- [25] HO, Jonathan; JAIN, Ajay; ABBEEL, Pieter. Denoising diffusion probabilistic models. *Advances in neural information processing systems*, 2020, 33: 6840.
- [26] Perera, M. V., Nair, N. G., Bandara, et al. SAR despeckling using a denoising diffusion probabilistic model. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20:1.